

Artículo original

Diagnóstico de piezas de alta velocidad odontológicas a partir del análisis de su sonido

Diagnosis of high-speed dental pieces from their sound analysis

John Jiménez Gómez, M.Sc

jojigo@gmail.com

Universidad Santiago de Cali, Colombia

Diego Nieto Gómez

dinigo0@gmail.com

Universidad del Valle, Cali-Colombia

Vanessa Collazos Valencia

vanico4@gmail.com

SENA, Cali-Colombia

Fecha de recepción: Febrero 18 de 2013

Fecha de aceptación: Mayo 31 de 2013

Palabras clave

Piezas de alta velocidad;
Adquisición de datos;
Procesamiento Digital de
Señales; Redes Neuronales..

Keywords

High speed dental piece; Data
acquisition; Digital Signal
Processing; Neural Networks.

**Colciencias
tipo 1**

Resumen

Las herramientas computacionales se desarrollan para ayudar a los profesionales en la determinación de ciertas anomalías en diferentes equipos. Estas herramientas buscan determinar algún daño sin necesidad de desmontar los equipos, con el fin de optimizar los procesos, en este caso, diagnosticar el funcionamiento de la pieza de alta velocidad odontológica. Este artículo presenta los resultados del desarrollo de un algoritmo computacional que permite obtener, a partir de los sonidos que generan las turbinas de las piezas de alta velocidad, el diagnóstico del estado en que ellas se encuentran. Lo anterior se logra mediante la captura del sonido de piezas de alta velocidad en buen y mal estado, con el fin de construir un banco de señales a partir de las cuales se extraen características en diferentes dominios para entrenar una red neuronal que diagnosticará el estado de la pieza. Con la implementación de este sistema ha sido posible alcanzar hasta un 81% de porcentaje de éxito en la clasificación de piezas defectuosas.

Abstract

The computational tools are developed to help professionals to determine anomalies in different equipment. These tools seek to determine any damage without disassembly for the purpose of optimize processes, in this case the operation of the diagnose high speed dental piece. This article presents the results of the implementation of a computational algorithm for obtaining, from the sounds generated by turbines high speed parts, in what state is this. This is accomplished by capturing the sound of high-speed components in good and bad state, in order to build a database from these sounds, each of these signals are extracted features in different domains to train a neural network, which diagnose the state of the workpiece. With the implementation of this system has been possible to achieve an 81% success rate for the classification of defective pieces.

.....

I. Introducción

El presente artículo se enfoca en el área de la odontología, específicamente en las piezas de alta velocidad. El funcionamiento normal de estas piezas genera ondas de sonido características que se dispersan en el medio produciendo un rango de vibración único; cuando la pieza se encuentra en mal estado, por el uso excesivo en materiales duros como la amalgama u otros, el desgaste natural o los golpes, su sonido cambia. Dado el avance y la potencialidad de las herramientas de Procesamiento Digital de Señales [PDS] y de inteligencia computacional (redes neuronales) se puede llegar a realizar el diagnóstico del estado de la pieza de alta velocidad a partir del sonido que ella genera.

El proyecto se enfocó en el diagnóstico de piezas de alta velocidad de la marca NSK Pana Air estándar a partir de la captura de su sonido, la extracción de sus características y el uso de redes neuronales entrenadas con el conjunto de características extraído.

II. Metodología

A. Construcción del banco de datos

La captura de las señales se realiza mediante un programa de captura de audio realizado en Matlab; se decidió utilizar el micrófono de condensador, porque presenta una buena relación señal–ruido y es poco sensible a las vibraciones. Tiene las siguientes características:

- » marca Keenione;
- » frecuencia de respuesta entre 75Hz- 16KHz;
- » sensibilidad de -52dB;
- » impedancia de 2KΩ; y
- » patrón de captura unidireccional.

La digitalización de la señal es realizada por la tarjeta de sonido de un PC portátil a una tasa de muestreo de 44100 M/s a una resolución de 16 bits; es almacenada en formato wav.

El banco de datos construido está compuesto por señales provenientes de piezas de alta velocidad en buen y mal estado, para un total de 72 señales, la Tabla 1 relaciona la cantidad de piezas de las que se obtuvo señal.

.....

Tabla 1. Cantidad de Piezas utilizadas

Buen estado	36
Mal estado	36

Con el fin de cumplir con la repetibilidad, las adquisiciones se realizaron en el mismo espacio físico, bajo los mismos parámetros ambientales y con la salida de aire de la unidad odontológica calibrada siempre a 35 lb.

B. Preprocesamiento de señales

Con el propósito de obtener una adecuada extracción de las características necesarias para entrenar el clasificador, se realizaron las siguientes etapas de pre-procesamiento de las señales:

Segmentación de la señal. La duración de la señal capturada es de diez (10) segundos, de estos se eliminan los dos (2) primeros, tiempo en que la pieza ya ha alcanzado su régimen de trabajo normal, se toma el segundo siguiente y se elimina el resto de la señal.

Selección, diseño y aplicación del filtro pasa banda. Con el fin de reducir el ruido en las señales adquiridas se consideró un filtro pasa banda adaptada al ancho de banda del micrófono. Por sus características de fase lineal y exactitud en la reconstrucción de la señal se seleccionó un filtro FIR de orden 10 (Proakis & Manolakis, 2007).

Selección, diseño y aplicación del filtro Notch de 60 Hz. Se utiliza con el fin de eliminar la componente de 60 Hz; mediante un proceso heurístico se obtuvo mejores resultados con un filtro FIR de orden 100; para la implementación de este filtro se adoptó lo establecido por Macías y Gamo (2010).

C. Procesamiento digital de señales (extracción de características)

El procesamiento digital de las señales para la extracción de características se realizó a cada una de las señales de audio; se extrajeron características en los dominios del tiempo, la frecuencia y el tiempo-frecuencia.

Dominio del tiempo. Para la selección de las características se examinaron trabajos similares (Stepinski & Lingvall, 2000; Arrabales, 1999; Jiménez & Loaiza, 2010). Algunas de las características más utilizadas que se extrajeron en el dominio del tiempo a las señales de audio son:

- » valor máximo de la señal;
- » valor de la media de la señal;
- » valor máximo de la energía; y
- » desviación estándar.

Dominio de la frecuencia. Las señales de audio también se pueden representar utilizando la densidad espectral de potencia, ya que este contiene información de los parámetros del modelo de la señal. Para la extracción de las características en este dominio se utilizó la parte real del Cepstrum, ya que no se considera la reconstrucción de la señal. Se tomaron como características los primeros veinte coeficientes Cepstrales de la señal de audio (Álvarez, 2001), en señales discretas el Cepstrum se define como (Hernando, 1993):

$$c(n) = \text{ifft}(\log|\text{fft}(\text{señal})|)$$

Los valores $c(n)$ son los coeficientes Cepstrales derivados de la transformada de Fourier; las características extraídas en este dominio corresponden a los primeros veinte coeficientes. La Figura 1 muestra los primeros veinte coeficientes Cepstrales extraídos a una señal de audio.




Figura 1. Primeros veinte coeficientes Cepstrales

Dominio tiempo –frecuencia. La transformada Wavelet se puede utilizar para señales continuas o señales discretas; ella consiste en la descomposición de una señal en un conjunto de señales escaladas y trasladadas de una función prototipo $\Psi(t)$ o wavelet madre. La transformada Wavelet se define como (Faundez & Fuentes, 2000):

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt$$

En este desarrollo se seleccionó la descomposición en tres niveles utilizando la función Daubechies de orden 4; las características se extraen, de todos los niveles de detalle el último nivel de aproximación. En la Figura 2 se observa la descomposición Wavelet de tres niveles de una señal de audio.

Adoptando lo hallado en Shuxiang & Wong (2004) y Zingerman & Dickstein (2000), las características extraídas a cada señal son:

- » media de la señal;
- » mediana de la señal;
- » valor máximo de la señal;
- » varianza de la señal;
- » desviación estándar de la señal;
- » covarianza de la señal, medida;
- » grado de uniformidad;
- » coeficientes de variación de Pearson;
- » coeficientes de asimetría de Pearson; y
- » entropía de la señal.

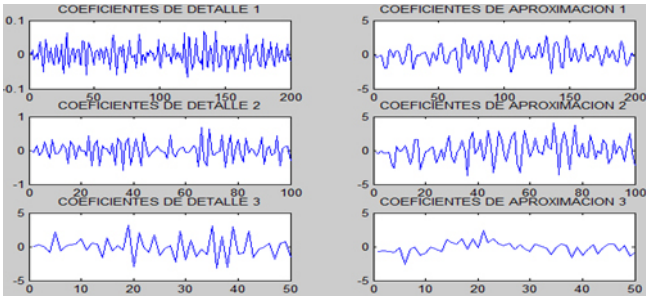


Figura 2. Descomposición Wavelet de tres niveles de una señal de audio

La Tabla 2 resume la cantidad de características extraídas en cada dominio.

Tabla 2. Cantidad de características en cada dominio

Dominio	Cantidad de características extraídas por cada señal
Tiempo	4
Frecuencia	20
Tiempo – Frecuencia	44
Total	68

La regla de aprendizaje del perceptrón multicapa [MLP] seleccionada para esta aplicación, en problemas donde los vectores de entrada tienen valores muy diferentes pueden ser demasiado lentas (López & Caicedo, 2003), por tanto, se deben normalizar los patrones, teniendo como consecuencia un tiempo corto de cómputo y una mejor generalización en el proceso de aprendizaje (Acosta & Zuluaga, 2000).

La normalización permite obtener, por fila, una media de 0 y una desviación estándar de 1, lo cual supone que los elementos de la fila son reales y no iguales (Jiménez & Loaiza, 2010). La siguiente es la expresión matemática de dicha herramienta.

$$y = (x - x_{mean}) \left(\frac{y_{std}}{x_{std}} \right) + y_{mean}$$

Los vectores de características que se le presentan a la red neuronal se seleccionan al azar, de manera que el 60% de las muestras se asignan al conjunto de entrenamiento, el 20% al conjunto de validación y el 20% al conjunto de pruebas; para esto, es necesario conocer las salidas de los patrones de entrenamiento, dado que es una red de aprendizaje supervisado. Con la utilización de la función de Matlab *dividerand* se logró obtener los tres conjuntos, en los cuales se requiere como entradas la matriz de patrones normalizada y la matriz de resultados (*target*). La función permite

seleccionar el porcentaje (fracción) de dichos conjuntos con respecto a la cantidad total de patrones. Las anteriores funciones (i.e., normalización y creación de subconjuntos de entrenamiento, validación y prueba) son realizadas por el programa, en el cual se implementa la red neuronal, con el fin de ingresar (a la red neuronal) en su etapa de entrenamiento patrones aleatorios extraídos de la matriz completa por la instrucción *dividerand*; la Figura 3 muestra el diagrama funcional de esta instrucción.

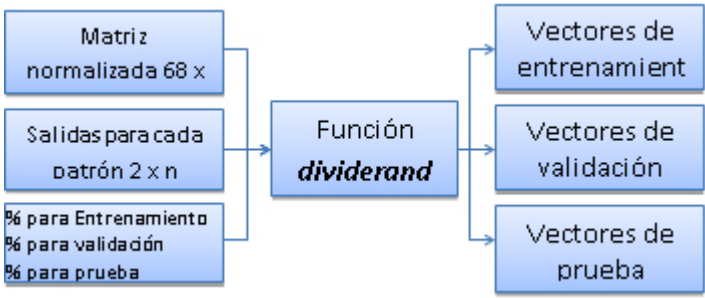


Figura 3. Algoritmo para la creación de los conjuntos de entrenamiento, validación y prueba

D. Redes neuronales artificiales

En aplicaciones de sonido, la revisión bibliográfica (Shuxiang & Wong, 2004; Martín del Brio & Molina, 2002) muestra que el Perceptrón Multicapa [MLP] es la Red Neuronal [RN] con más aplicaciones; el algoritmo de aprendizaje es supervisado, lo que permite que sus resultados sean evaluados y se realicen, de ser necesario, modificaciones a la red.

El procedimiento de entrenamiento permite presentar al Perceptrón un conjunto de patrones de entrada; los pesos de la red son ajustados en cada una de las capas, de manera que la salida coincida con los patrones de entrada establecidos. Para este desarrollo se utilizó una arquitectura *Backpropagation* con tres capas, una de entrada, una oculta y una de salida; esta última tiene *dos salidas*, las cuales indican si la señal examinada asociada a una pieza de alta está en buen estado, mal estado o si no logra diagnosticarla.

La capa de entrada está constituida por 68 neuronas, la misma cantidad de características; para el entrenamiento, en la capa oculta se trabajó con función de activación *tangente sigmoidal* y se varió la cantidad de neuronas en 5, 10, 15 y 20, para no perder generalización y no entorpecer el aprendizaje de la RNA (Jiménez, 2008); en la capa salida se presentan dos neuronas con función de activación *logarítmica sigmoidal* que entregan las salidas en un rango entre 0 y 1. La estructura de la red neuronal implementada se muestra en la Figura 4.




Figura 4. Red implementada para el diagnóstico

III. Pruebas y resultados

Las pruebas realizadas en los ensayos incluyen el entrenamiento ingresando patrones a la red neuronal que contenían todas las características extraídas a las señales de las piezas de alta velocidad; la matriz de características está constituida por la misma cantidad de piezas en buen y mal estado.

Al realizar las pruebas con los sonidos de las turbinas de las piezas de alta velocidad, se utilizan varias combinaciones de la red neuronal, con el fin de observar cuál tiene mejor desempeño. Las diferentes configuraciones probadas se obtuvieron con la combinación de los parámetros que indica la Tabla 3.

Tabla 3. Combinación de parámetros de entrenamiento utilizados

Número de neuronas en la capa oculta	Número de épocas de entrenamiento	Algoritmo de entrenamiento	Método de entrenamiento
5 15 10 20	5000 10000	Traincgb	Parada anticipada
		Traincgf	
		Traincgp	
		Traingd	
		Traingda	
		Traingdm	
		Traingdx	
		Trainlm	
		Trainoss	
		Trainrp	
		Trainscg	

Ya que las salidas de la RN son valores decimales entre 0 y 1, fue necesario adoptar un criterio de decisión para ajustar su desempeño; de tal forma, se definió un valor de umbral para que si la salida lo supera, se convierte en un valor de 1, y si no lo supera, el valor se lleve a cero. La Tabla 4 plantea esta situación de acuerdo con las salidas de la RN. La asignación del valor de dicho umbral obedece a criterios heurísticos, las pruebas con diferentes métodos en la asignación del valor de umbral a las dos salidas de la red neuronal dio como mejor resultado el redondeo a cero (0) o uno (1): los valores mayores a 0,5 se llevan a 1, los menores a 0.

Tabla 4. Diagnóstico de la RN de acuerdo con el valor de sus salidas

	Diagnóstico			
	Buena	Mala	No reconoce	
Neurona de salida 1	1	0	0	1
Neurona de salida 2	0	1	0	1

En consultas a profesionales de la salud oral, ellos coincidieron en darle mayor importancia al diagnóstico acertado de piezas en mal estado, sin restarle importancia al diagnóstico de las piezas en buen estado; lo anterior permitió definir la red84 como la red con mejor desempeño, con valores del 81.25% de diagnóstico acertado de piezas defectuosas y el 56.25% de piezas no defectuosas. La topología de la RN y su matriz de confusión obtenida con la configuración de la red84 se muestra en la Tabla 5.

Tabla 5. Topología y matriz de confusión de la RN con mejor desempeño.

Tipo de entrenamiento			Parada anticipada	
Número de neuronas en la capa oculta			15	
Algoritmo de entrenamiento			traincgb	
Matriz de confusión	Buenas	Malas	No sabe	% de aciertos
Piezas buenas	5	9	2	56,25
Piezas malas	13	3	0	81,25

El entrenamiento y la simulación se llevó a cabo ingresando patrones a cada RN por separado; la Tabla 6 muestra las 21 redes con mejor desempeño.

Tabla 6. Redes con mejor desempeño

# Red	Piezas buenas	Aciertos	No Aciertos	No Reconocidas	Piezas malas	Aciertos	No Aciertos	No Reconocidas
red1	16	6	9	1	16	12	2	2
red7	16	7	9	0	16	13	3	0
red9	16	5	9	2	16	13	2	1
red14	16	7	9	0	16	12	4	0
red17	16	7	7	2	16	13	3	0
red18	16	9	7	0	16	11	5	0
red40	16	9	7	0	16	11	5	0
red41	16	9	7	0	16	11	5	0
red45	16	4	12	0	16	14	2	0
red48	16	9	7	0	16	11	5	0
red49	16	7	9	0	16	11	5	0
red50	16	10	6	0	16	12	4	0

Tabla 6. Redes con mejor desempeño (cont.)

# Red	Piezas buenas	Aciertos	No Aciertos	No Reconocidas	Piezas malas	Aciertos	No Aciertos	No Reconocidas
red56	16	4	12	0	16	14	2	0
red59	16	9	7	0	16	11	5	0
red60	16	7	9	0	16	11	5	0
red61	16	10	6	0	16	12	4	0
red78	16	6	10	0	16	13	3	0
red80	16	7	9	0	16	12	4	0
red82	16	7	9	0	16	11	5	0
red83	16	7	9	0	16	12	4	0
red84	16	9	5	2	16	13	3	0

Conclusiones

Se construyó una herramienta capaz de diagnosticar el estado de funcionamiento de las piezas odontológicas de alta velocidad, con base en el sonido que ellas generan en su funcionamiento bajo un régimen normal de trabajo.

El uso de características adquiridas en diferentes dominios asegura un mejor desempeño de la aplicación desarrollada.

Las pruebas y resultados indican que la utilización de herramientas de procesamiento digital de señales e inteligencia computacional permite tener resultados acertados en la detección de piezas en mal estado, objetivo del proyecto, aun cuando el banco de datos es de tamaño reducido.

El desempeño obtenido sólo aplica para piezas de marca NSK, ya que el sistema se desarrolló adquiriendo señales de piezas de esta marca. La herramienta desarrollada permite construir nuevos bancos de datos para realizar el diagnóstico a piezas de diferentes marcas.

La revisión bibliográfica no evidencia la existencia de fuentes que se refirieran al estudio del estado de las piezas de alta velocidad; la mayoría de documentos se refiere a la contaminación auditiva que ello genera; con la detección del mal estado de funcionamiento de la pieza, de forma indirecta, se está colaborando con la detección de la fuente que más aporta contaminación sonora en el consultorio, para su mitigación.

El desarrollo de este tipo de proyectos es muy útil, ya que permite ahorros de tiempo, dinero y esfuerzo, en la solución de problemas que se pueden evitar en un determinado tiempo. Con esto se refiere al mantenimiento predictivo de cualquier equipo que utilice rodamientos, como una pieza de alta velocidad. ^{S&T}

Referencias bibliográficas

- Acosta, M. & Zuluaga, C. (2000). *Tutorial sobre redes neuronales aplicadas en ingeniería eléctrica y su implementación en un sitio web* [proyecto de grado]. Universidad Tecnológica de Pereira: Colombia.
- Álvarez, A. (2001). Fundamentos del reconocimiento automático de la voz [en línea - material de clase de la Universidad Politécnica de Madrid, España]. Recuperado de <http://tamarisco.datsi.fi.upm.es/ASIGNATURAS/FRAV/apuntes/extraccion.pdf>
- Arrabales, R. (1999). Extracción de Características de la Señal de Voz. Recuperado de http://www.conscious-robots.com/raul/voz_old/voz_extr.htm
- Macías, J. & Gamio, J. (2010). *Laboratorio de instrumentación electrónica* [guía docente]. Alcalá, España: Universidad de Alcalá
- Faundez, P. & Fuentes, Á. (2000). *Procesamiento digital de señales acústicas utilizando wavelets* [en línea - documento del Instituto de Física y Matemática de la Universidad Austral de Chile, UACH]. Recuperado de http://www.hst.aau.dk/~vhooraz/tesis_wavelet.pdf
- Hernando, F. (1993). *Técnicas de procesamiento y representación de la señal de voz para el reconocimiento del habla en ambientes ruidosos* [tesis doctoral]. Universidad Politécnica de Cataluña: España: Disponible en <http://www.tdx.cat/handle/10803/6911>
- Jiménez, J. (2008). *Implementación de un algoritmo para la detección de defectos en tuberías mediante ensayo no destructivo de materiales por ultrasonido* [tesis de maestría]. Universidad del Valle: Cali, Colombia
- Jiménez, J. & Loaiza, H. (2010). Detección y caracterización de defectos en tuberías metálicas en pruebas ultrasónicas por inmersión. *El Hombre y la Máquina*, 22(34), 56-67
- López, J. & Caicedo, E. (2003). Una aproximación práctica a las redes neuronales artificiales. Cali, Colombia: Universidad del Valle
- Martín-del-Brio, B. & Molina, A. (2002). *Redes neuronales y sistemas difusos* [2a ed.]. México D.F., México: Alfaomega
- Proakis, J. & Manolakis, D. (2007). *Tratamiento digital de señales*. Madrid, España: Pearson
- Shuxiang, J. & Wong, S. (2004). Development of an automated ultrasonic testing system [en línea]. *NDT.net*, 10(4). Recuperado de <http://www.ndt.net/article/icem2004/papers/184/184.htm>
- Stepinski, T. & Lingvall, F. (2000). Automatic defect characterization in ultrasonic. En *Proceedings of 15th World Conference on Nondestructive Testing*. Recuperado de <http://www.ndt.net/article/wcndt00/papers/idn393/idn393.htm>
- Zingerman, A. & Dickstein, P. (2000). *Wavelets entropy and zero-crossing white-noise test applied to ultrasonic classification of degrading adhesive joints* [Poster en ECNDT 2006]. Recuperado de <http://www.ndt.net/article/ecndt2006/doc/P200.pdf>

Currículum vitae

John Jiménez Gómez

Ingeniero Electricista de la Universidad del Valle (1997), Especialista en Docencia para la Educación Superior de la Universidad Santiago de Cali (1999), Especialista en Electromedicina y Gestión Tecnológica Hospitalaria de la Universidad Autónoma de Occidente (2003) y Magíster en Electrónica de la Universidad del Valle (2008). Profesor de la Facultad de Ingeniería de la Universidad Santiago de Cali, vinculado al grupo de investigación en Instrumentación Electrónica [GIE].

Diego Nieto Gómez

Técnico Profesional en Mantenimiento Electrónico del SENA (2000), Técnico en Electromedicina del IIEE (2001), Bioingeniero de la Universidad Santiago de Cali (2012), Ingeniero de la oficina de mantenimiento de la Escuela de Odontología de la Universidad del Valle.

Vanessa Collazos Valencia

Bioingeniera de la Universidad Santiago de Cali (2013), estudiante de Mantenimiento Eléctrico Industrial en la institución pública educativa, Servicio Nacional de Aprendizaje [SENA].